

利用神经网络优化关联存储模型^{*}

路明哲 陈锦莉 方志良 刘福来 母国光

(南开大学现代光学研究所, 天津, 300071)

摘要: 利用神经网络的优化功能, 根据内容寻址过程的特点, 对二元关联存储模型进行了优化处理, 并对网络的存储容量及容错能力进行了统计分析。结果表明优化后的二元神经网络模型的性能有了很大的提高。

关键词: 二元关联存储模型, 优化过程。

引言

迄今, 对人工神经网络已进行了大量的研究^[1~5]。神经网络中信息是以并行方式传递和处理的, 网络的性能是由网络的结构和网络中神经元之间的互联权重决定的。网络根据被处理信息建立互联权重的过程称作网络的学习过程。如误差反传算法(Backpropagation)、模拟退火算法^[6]。其中, 误差反传算法是最有效的算法之一, 可用于多层网络的学习过程。

由于光学信息处理系统具有大容量和高度并行等特点, 光学方法或光电混合方法被认为是实现人工神经网络的重要途径之一^[7]。但一般说来, 光学系统的运算精度较差, 由误差反传等学习算法所构成的多灰度阶互联权重矩阵并不适合于光学神经网络系统实现, 即使采用电子学方法, 硬件实现也十分困难。为此, 提出了一些二元神经网络模型, 并利用一些算法进一步改善它们的性能^[8,9]。

本文利用神经网络中 Hopfield 模型的优化功能, 通过改变内容寻址过程中模拟输出量, 对二元关联存储模型进行了优化处理。并采用随机存储矢量集对优化后的网络性能进行了统计分析。

1 Hopfield 模型^[11]

对于一组给定的被存储矢量 $V_i^{(m)}$, $i = 1, 2, \dots, N$, $m = 1, 2, \dots, M$ 。这里 N 为网络中神经元的数目, M 为存储的矢量数。在 Hopfield 模型中, 网络的关联矩阵元为

本文 1992 年 10 月 2 日收到, 最后修改稿 1992 年 11 月 30 日收到。

*国家自然科学基金资助课题。

$$\begin{cases} T_{ij} = \sum_m V_i^{(m)} V_j^{(m)}, \\ T_{ij} = 0. \end{cases} \quad (1)$$

每个神经元的状态由其它神经元的状态决定，其演化过程为

$$V_i = \begin{cases} 1 & (\text{当 } \sum_j T_{ij} V_j > U_i), \\ -1 & (\text{其它情况下}). \end{cases} \quad (2)$$

式(2)中 U_i 为系统的阈值，一般取 $U_i = 0$.

在 Hopfield 模型中，当网络的神经元状态为 $\{V_j^{(m0)}\}$ 时，能量函数定义为

$$E = -\frac{1}{2} \sum_i \sum_j T_{ij} V_i^{(m0)} V_j^{(m0)} - U_i V_i^{(m0)}. \quad (3)$$

可以证明，网络按照式(2)进行的演化过程是使网络能量单调下降的过程^[10]. 这样，对于一个优化问题，如果它的能量函数可以写成式(3)的形式，就可以利用 Hopfield 模型的神经网络进行优化.

2 二元神经网络的优化

设某一个神经网络模型的关联权重矩阵为 $\{T_{ij}\}$ ，当 $V^{(m0)}$ 对网络进行内容寻址时，网络第 i 个神经元的模拟输出值为

$$u_i^{(m)} = \sum_j T_{ij} V_j^{(m0)}. \quad (4)$$

式(4)中 $V^{(m0)}$ 为网络的寻址矢量。第 i 个神经元的状态则由模拟输出量 $u(i)$ 与阈值进行比较后决定。假设网络可以正确识别某个存储矢量，当寻址矢量和存储矢量有差别时，即它们之间的 Hamming 距离不为零时，模拟输出量发生变化。当 Hamming 距离大到可以改变模拟输出量和阈值的比较结果时，会出现误判。因此，模拟输出量和阈值之间的差别既反映了网络的存储能力，也表明了网格的容错能力^[11]。

我们提出一个对互联权重矩阵的优化过程，该优化过程使每一个模拟输出值和阈值的差别都向某一个特定的值逼近。存储矢量集在第 i 个神经元的输出值只与 $\{T_{ij}, j=1, 2, \dots, N\}$ 有关^[9]，对 $\{T_{ij}, j=1, 2, \dots, N\}$ 的优化只需根据存储矢量集在第 i 个神经元的输出进行。当对关联矩阵的第 i_0 列进行优化时，这个过程的能量函数可以表示为

$$\begin{aligned} E(i_0) = & \sum_m [u^{(m)}(i_0) - V_{i_0}^{(m)} Dn]^2 + \sum_{j1, j2} \left(\sum_m V_{i_0}^{(m)} V_{j1}^{(m)} \right) T_{i_0, j1} T_{i_0, j2} \\ & - \sum_j T_{i_0, j} (2Dn \sum_m V_{i_0}^{(m)} V_{j}^{(m)}). \end{aligned} \quad (5)$$

其中 Dn 是一个正的常数。式(5)中，去掉了常数项和常数因子。对于二元互联权重矩阵， T_{ij} 只能取值为 1 或 -1，我们可以把 $\{T_{ij}, j=1, 2, \dots, N\}$ 当作存储矢量。与式(3)进行比较，可以得出优化所用的关联矩阵元为

$$W_{ij} = \sum_m V_i^{(m)} V_j^{(m)}, \quad (6)$$

阈值为

$$U_i = 2Dn \sum_m V_i^{(m)} V_j^{(m)}. \quad (7)$$

采用离散型非同步 Hopfield 模型的演化过程，就可以对互联矩阵权重进行优化，使各个存储矢量的模拟输出结果逼近同一个值。

3 结果

我们采用模拟的方法，对优化后的二元关联存储模型的性能进行了系统分析。存储容量和容错能力是关联存储模型的最主要特性。在存储容量的测试中，选用多组随机的存储矢量，按 Clipped 模型构成互联权重的初值，经上述的优化过程得到相应的优化互联权重矩阵。通过模拟原矢量和有噪声情况下的寻址过程，得出二元优化关联存储模型的存储容量和收敛半径。网络的联想过程按照式(2)所描述的动力学过程演化，直至给出稳定的输出。网络的联想效果由输出矢量与存储矢量的重叠度来表示，重叠度定义为

$$q = \sum_j \frac{V_j^1 V_j^2}{N}. \quad (8)$$

受微机速度和容量的限制，我们只选择了 1000 个 16 维的存储矢量进行统计分析。定义 $\langle q \rangle > 0.985$ 时，网络可以正确识别存储矢量。图 1 给出了优化二元关联存储模型和 Hopfield 模型的存储容量。可以看出，经过优化，网络的存储能力有了很大的提高。这里应注意，Hopfield 模型是多灰度级的关联模型。

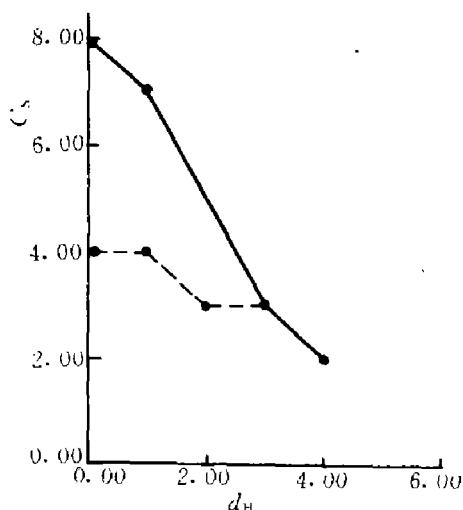


图 1 关联存储模型的存储容量
(虚线为 Hopfield 模型；实线为优化模型)
Fig. 1 Storage capacity of the associative
models
(- - -: Hopfield model; ——: Optimum model)

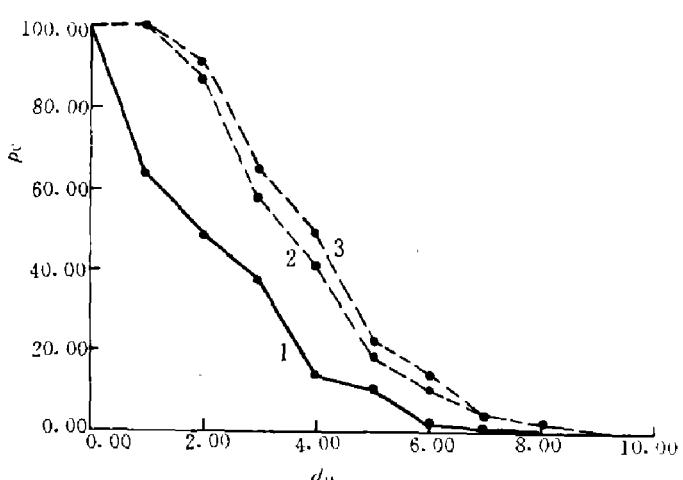


图 2 几种模型的收敛几率
1: Hopfield 模型；2: 优化模型；3: 部分优化模型
Fig. 2 Convergence of associative models
1: Hopfield model; 2: optimum model;
3: modified optimum model

为了进一步观察优化过程对模型容错能力的改善, 我们选用下列 5 个 16 维矢量作为存储矢量分别构成优化的二元关联矩阵和 Hopfield 模型关联矩阵, 即

$$\begin{aligned} A: & \{-1\ 1\ 1\ 1\ 1\ 1\ -1\ 1\ -1\ -1\ 1\ 1\ -1\ 1\ -1\}, \\ B: & \{1\ 1\ -1\ 1\ 1\ -1\ 1\ -1\ -1\ -1\ 1\ 1\ 1\ -1\ 1\}, \\ C: & \{-1\ -1\ -1\ -1\ 1\ -1\ 1\ -1\ -1\ -1\ 1\ 1\ 1\ -1\ 1\}, \\ D: & \{-1\ -1\ -1\ 1\ -1\ 1\ 1\ -1\ 1\ -1\ 1\ 1\ 1\ -1\ 1\ -1\}, \\ E: & \{-1\ -1\ -1\ 1\ -1\ -1\ -1\ -1\ -1\ -1\ 1\ -1\ -1\ -1\ 1\ 1\}. \end{aligned}$$

将存储矢量空间中所有可能的矢量作为网络的输入矢量进行内容寻址, 所得到的结果能够全面地反映互连矩阵的性能。我们得到了系统中假态和振荡态的数目, 假态、振荡态和存储态的收敛几率, 不同 Hamming 距离时的收敛几率及达到稳定输出平均所需的迭代次数。结果列于表 1 和图 2。

表 1 关联存储统计结果
Table 1 Associative memory statistics

	百分率	
	优化二元模型	Hopfield 模型
存储态收敛几率	42.2	9.5
假态收敛几率	52.4	66.1
振荡态收敛几率	5.3	24.4
平均迭代次数	4.62	4.76

在优化过程中我们发现, 关联矩阵初值的选取对优化结果没有影响, 这说明此过程是在整个空间上的优化, 可以达到最优结果。内容寻址的模拟输出与阈值的差别越大, 网络的存储能力和容错能力就越强。显然, 我们上述的优化方法采用式(5)作为能量函数是有一定缺陷的, 即在优化过程中, 对于模拟输出 $U_i^{(m)} > Dn$ 的情况, 也要求向 Dn 逼近, 这对于网络性能的改善没有益处, 同时也对网络的优化过程有一定的约束。为解决这个问题, 我们将能量函数改写成

$$E(i_0) = \sum_m [u_i^{(m)}(i_0) - V_i^{(m)} Dn]^2, \quad (9)$$

其中 $\{V_i^{(m)}\}$ 集合为在第 i_0 个神经元模拟输出小于的存储矢量集合。相应的, 优化时采用的互连权重矩阵为

$$W_{ij} = \sum_m V_i^{(m)} V_j^{(m)}, \quad (10)$$

阈值为

$$U_i = 2Dn \sum_m V_i^{(m)} V_j^{(m)}. \quad (11)$$

这样优化后的关联存储模型的收敛半径也示于图 2, 可以看出, 容错能力有了进一步改善。

4 结束语

本文提出了一种对二元关联存储模型优化的方法，我们认为这种优化过程是全空间的优化，可以达到最优结果。我们对优化后的网络进行了统计分析，结果表明该优化过程可以使网络的存储容量和容错能力都有较大的提高，存储态的收敛几率和收敛半径也有改善。

参考文献

- 1 Hebb D O. *The Organization of Behavior*, New York: Wiley, 1949
- 2 Hopfield J J. *Proc. Natl. Acad. Sci. USA*, 1982, **79**:2554
- 3 Psaltis D, Farhat N. *Opt. Lett.*, 1985, **10**:98
- 4 Peak E G, Psaltis D. *Opt Eng.*, 1987, **26**:428
- 5 Gardner E, Derrida B. *J. Phys.*, 1988, **A21**:271
- 6 焦李成. 神经网络系统理论, 西安: 西安电子科技大学出版社, 1989
- 7 Abu-Mostafa Y S, Psaltis D. *Sci. Amer.*, 1987, (3):66
- 8 黄五群, 高成群, 陈天伦等. 光学学报, 1990, **10**:446
- 9 Mu G G, Lu M Z, Zhan Y L. *Optik*, 1991, **89**(1):11
- 10 Tank D W, Hopfield J J. *Sci. Amer.*, 1987, **256**:62
- 11 Lu M Z, Zhan Y L, Mu G G. *Optik*, 1992, **91**:178

OPTIMIZATION OF ASSOCIATIVE MEMORY MODEL BY NEURAL NETWORK

Lu Mingzhe, Chen Jinli, Fang Zhiliang,
Liu Fulai, Mu Guoguang

(Institute of Modern Optics, Nankai University, Tianjin 300071, China)

Abstract: In this paper, based on the content addressing process of associative memory, the optimization method of binary associative model is proposed by using a neural network. The error tolerance of the optimum model is analyzed statistically. It is shown that the performance of the optimum model is improved.

Key words: binary associative memory model, optimization.

* The project supported by the National Natural Science Foundation of China.